

MLP NEURAL NETWORK AS A TOOL FOR IMAGES COMPUTER ANALYSIS

Summary

A significant development of programmatic techniques, used in neural simulation, has caused an increase of interest in the methods of artificial intelligence in scientific research. The issue of the artificial network of neurons makes it possible for us to use them in the process of identification the objects seen as digital images. The aim of the work is to generate neural network, which is able to make a classification of butterflies of the Papilionidae family, protected species in Poland, basing on an information coded in the graphic form.

SIEĆ NEURONOWA TYPU MLP JAKO NARZĘDZIE W KOMPUTEROWEJ ANALIZIE OBRAZÓW

Streszczenie

Znaczący rozwój technik informatycznych, mający m.in. miejsce w dziedzinie modelowania neuronowego, spowodował wzrost zainteresowania metodami sztucznej inteligencji w kontekście ich wykorzystania w badaniach naukowych. Jednym z aspektów sztucznych sieci neuronowych jest możliwość ich zastosowania w procesie identyfikacji obiektów występujących w postaci obrazów cyfrowych. Celem pracy jest wygenerowanie sieci neuronowej dokonującej klasyfikacji motyli należących do rodziny Papilionidae, objętych ochroną gatunkową na terenie Polski, w oparciu o informację zakodowaną w postaci graficznej.


1. Wprowadzenie

Jednym z aspektów Sztucznych Sieci Neuronowych (SSN) jest ich wykorzystanie jako narzędzi klasyfikacyjnych w zagadnieniach związanych z komputerową analizą obrazów cyfrowych [5]. Służą one najczęściej jako klasyfikatory, pozwalając na identyfikację odpowiednio przygotowanych obrazów. Rozwój technologii, zdecydowanie szybsza praca komputerów, jak i większa dostępność oprogramowania do obróbki grafiki sprawiły, że modelowanie neuronowe jest procesem coraz częściej stosowanym w zagadnieniach związanych z rolnictwem i inżynierią rolniczą. Badacze z zainteresowaniem korzystają z narzędzi, które pozwalają na wnioskowanie z danych zawartych w postaci obrazów cyfrowych. Modele neuronowe stanowią uzupełnienie klasycznych technik identyfikacji obrazów. Cechuje je znacznie szybsze działanie w porównaniu z tradycyjnymi metodami komputerowymi [2]. Elementem niezbędnym do właściwego działania SSN jest jej zaprogramowanie, tak by w właściwy sposób „reagowała” na zadane bodźce w postaci danych z obrazów cyfrowych. Sieć MLP (Multi Layer Perceptron – perceptron wielowarstwowy) to model neuronowy generowany tzw. metodą „z nauczycielem”. SSN programuje się poprzez udostępnienie odpowiednio opisanych przypadków uczących. Są to wektory informacji zapisane w pliku wygenerowanym podczas akwizycji obrazu cyfrowego [3]. W pracy wykazano, iż możliwa jest identyfikacja motyli z rodziny Papilionidae (objętych ochroną gatunkową na terenie Polski), na podstawie ich dwuwymiarowych obrazów cyfrowych.

2. Generowanie zbioru uczącego

Zbiór uczący przeznaczony do budowy modelu neuronowego wygenerowano na podstawie stu trzydziestu czterech obrazów cyfrowych, czterech gatunków motyli z ro-

dziny Papilionidae: Paź żeglarz (*Iphiclides podalirius* - rys. 1), Paź królowej (*Papilio machano* - rys. 2), Niepylak apollo (*Parnassius Apollo* - rys. 3) oraz Niepylak mnemoza (*Parnassius mnemosyne* - rys. 4).




Rys. 1. Paź żeglarz (*Iphiclides podalirius*)

Fig. 1. *Iphiclides podalirius*




Rys. 2. Paź królowej (*Papilio machano*)

Fig. 2. *Papilio machano*



Rys. 3. Niepylak apollo (*Parnassius Apollo*)

Fig. 3. *Parnassius Apollo*



Rys. 4. Niepylak mnemoza (*Parnassius mnemosyne*)

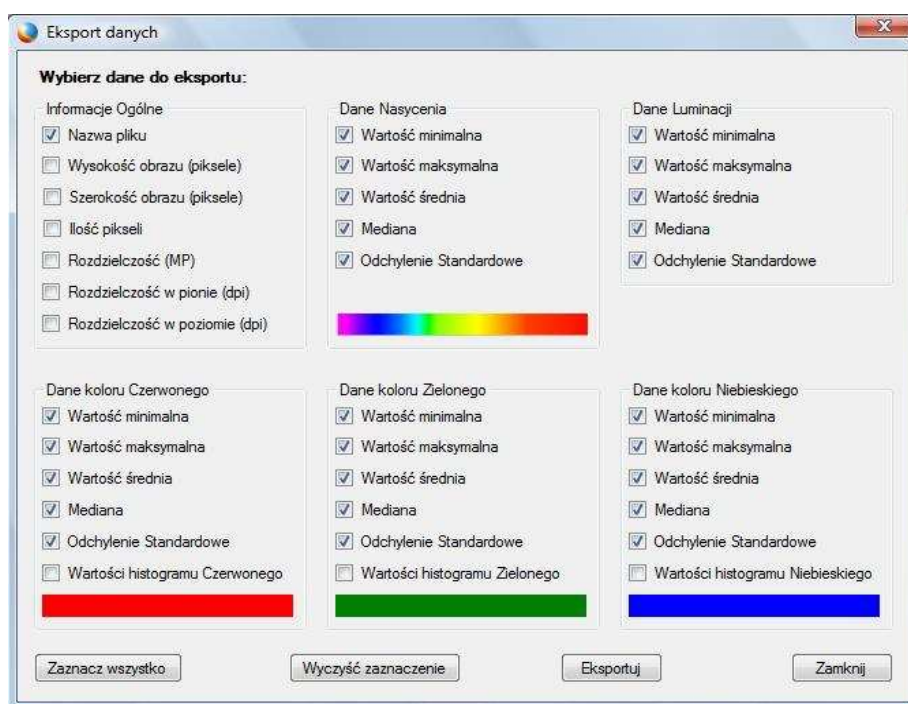
Fig. 4. *Parnassius mnemosyne*

Obrazy te przeanalizowano w autorskim systemie informatycznym **PIAO** (*Przetwarzanie i Analiza Obrazów*) [7]. Analiza obejmowała ekstrakcje oraz pozyskanie z obrazów cyfrowych cech charakterystycznych w postaci 26 następujących zmiennych reprezentatywnych (rys. 5):

- nazwa pliku – nazwa gatunku,
- nasycenie minimalne,
- nasycenie maksymalne,
- nasycenie średnie,
- nasycenie mediana,
- nasycenie StdDev – odchylenie standardowe,

- luminacja minimum,
- luminacja maksimum,
- luminacja średnia,
- luminacja mediana,
- luminacja StdDev – odchylenie standardowe,
- czerwony minimum,
- czerwony maksimum,
- czerwony średnia,
- czerwony mediana,
- czerwony StdDev – odchylenie standardowe,
- zielony minimum,
- zielony maksimum,
- zielony średnia,
- zielony mediana,
- zielony StdDev – odchylenie standardowe,
- niebieski minimum,
- niebieski maksimum,
- niebieski średnia,
- niebieski mediana,
- niebieski StdDev – odchylenie standardowe.

Pozyskane dane z każdego z przeanalizowanych obrazów w systemie **PIAO** zapisano do zewnętrznego pliku *.csv. Wstępna analiza wygenerowanego zbioru uczącego pozwoliła stwierdzić, iż zmienne: *czerwony minimum* i *maksimum*, *zielony minimum* i *maksimum* oraz *niebieski minimum* i *maksimum* przyjmowały wartości dla minimum 0, a dla maksimum 255, dlatego też zostały one usunięte. Następnie po porównaniu wartości zmiennych *luminacji minimalnej* i *maksymalnej* stwierdzono, iż nie mają one istotnego wpływu na proces generowania *SSN*. Ich wartości były bliskie 0 (dla *luminacji minimalnej*) lub bliskie 1 (dla *luminacji maksymalnej*), dlatego też usunięto je ze zbioru uczącego. Tak przygotowany plik wprowadzono do pakietu **STATISTICA** v. 4.0.



Rys. 5. Eksport danych z zaznaczonymi zmiennymi reprezentatywnymi

Fig. 5. Data export with selected representative variables

3. Generowanie modeli neuronowych

Po wprowadzeniu wygenerowanego zbioru uczącego do pakietu *STATISTICA* v. 4.0., w celu wytworzenia *SSN* użyto opcji „Automatyczny projektant”. Tak wytworzone sieci nie spełniały ogólnie przyjętych kryteriów jakości. Cechały się „przeuczeniem”, co skutkowało ich nieprawidłowym działaniem. Wobec tego przystąpiono do wykonania analizy wrażliwości wygenerowanych modeli neuronowych na poszczególne zmienne wejściowe. Celem takiego działania była identyfikacja a następnie odrzucenie zmiennych nieprzydatnych w procesie wytwarzania modeli neuronowych. Z przeprowadzonej analizy wynikało, iż zmienne: *czerwony mediana*, *zielony mediana* i *niebieski mediana* nie są istotne w procesie uczenia sieci, dlatego też usunięto je ze zbioru uczącego. W końcowym etapie w zbiorze uczącym znalazło się 13 zmiennych wejściowych (rys. 6):

- *nazwa pliku* – nazwa gatunku,
- *nasylenie średnie*,
- *nasylenie mediana*,
- *nasylenie StdDev* – odchylenie standardowe,
- *luminacja średnia*,
- *luminacja mediana*,
- *Luminacja StdDev* – odchylenie standardowe,
- *czerwony średnia*,
- *czerwony StdDev* – odchylenie standardowe,

- *zielony średnia*,
- *zielony StdDev* – odchylenie standardowe,
- *niebieski średnia*,
- *niebieski StdDev* – odchylenie standardowe.

Redukcja liczby zmiennych wejściowych pozwoliła na uzyskanie optymalnej proporcji przypadków uczących w stosunku do liczby zmiennych przyjętej w procesie generowania *SSN* w proporcji: 10:1. Tak przygotowany zbiór ponownie wprowadzono do obróbki w pakiecie *STATISTICA* v. 4.0. W tym przypadku uzyskano istotną poprawę działania sieci neuronowych. W programie przetestowano 32 sieci. Zachowanych zostało 10 najlepszych. Optymalną okazała się sieć neuronowa typu *MLP* o strukturze 4:2-3:1. Współczynnik poprawnych klasyfikacji tej sieci wyniósł 0,878788. Efektywność sieci została oceniona przez system jako dobra.

Wygenerowana sieć *MLP* 4:2-3:1 (rys. 7) charakteryzuje się 4 zmiennymi wejściowymi i 1 zmienną wyjściową. Posiada 2 warstwy ukryte. W pierwszej warstwie znajdują się 2 neurony, zaś w drugiej 3. Uczenie sieci przeprowadzono przy użyciu algorytmów: wstecznej propagacji błędów *BP* (ang. *Back Propagation*) w 50 epokach, gradientów sprzężonych *CG* (ang. *Conjugate Gradients*) w 50 epokach. Przeprowadzono również douczenie sieci wykorzystując algorytm gradientów sprzężonych *CG85b* (wybrano metodę *b* od ang. *best*) w 85 epokach.

The screenshot shows an Excel spreadsheet titled 'Zbiór uczący3 - Microsoft Excel użytkownik niekomercyjny'. The spreadsheet contains 28 rows of data, each representing a different 'nazwa pliku' (file name). The columns represent various input variables: 'nazwa pliku', 'nasylenie_sre', 'nasylenie_med', 'nasylenie_stddev', 'luminacja_srednia', 'luminacja_mediana', 'luminacja_stddev', 'czerwony_srednia', 'czerwony_stddev', 'zielony_srednia', 'zielony_stddev', 'niebieski_srednia', and 'niebieski_stddev'. The data values are numerical, representing the characteristics of each file.

Rys. 6. Zbiór uczący zawierający 13 zmiennych wejściowych
Fig. 6. Learning file with 13 input variables

The screenshot shows the 'Edytor zbioru sieci (Zbiór uczący3)' window in STATISTICA. It displays a table of generated neural networks. The table has columns for 'Typ' (Type), 'Wejścia' (Inputs), 'Ukryte' (Hidden), 'Ukrytel(2)' (Hidden 2), 'Błąd ucz.' (Learning Error), 'Błąd wal.' (Validation Error), 'Błąd tot.' (Total Error), 'Jakość ucz.' (Learning Quality), 'Jakość wal.' (Validation Quality), 'Jakość tot.' (Total Quality), 'Indeks' (Index), and 'Uczenie' (Training). The table lists 10 different network configurations, with the 10th configuration (MLP 4:2-3:1) highlighted in red, indicating it is the optimal network.

Rys. 7. Zbiór wytworzonych sieci neuronowych
Fig. 7. The set of neural networks produced

Wygenerowany model neuronowy charakteryzuje się jakością walidacyjną na poziomie 0,878788. Jakość uczenia tej sieci wynosi 0,776119, natomiast jakość testowa 0,676470. Błędy uczenia, walidacyjny oraz testowy wynoszą odpowiednio: 0,3267996; 0,2853999 i 0,3878973.

Jakość sieci to miara precyzji, z jaką sieć wyznacza zmienną wyjściową dla danych zmiennych wejściowych. Jakość wyznacza się niezależnie dla zbioru uczącego, testowego i walidacyjnego. Wartość 1 jest najwyższa. Im wynik jakości sieci bliżej jedności tym sieć jest lepsza. Sieci o niskich wartościach jakości typu 0,1 itp. należą do sieci działających niepoprawnie. Dla wytworzonej sieci *MLP* 4:2-3:1 jakość jest proporcją prawidłowo zakwalifikowanych przypadków. Na podstawie 'Analizy wrażliwości' (rys. 8) ustalono, że w procesie uczenia zostały wykorzystane zmienne 'zielony StdDev' (ranga 1), 'niebieski StdDev' (ranga 2), 'zielony średnia' (ranga 3), 'nasylenie średnie' (ranga 4). Okazało się, że reszta zmiennych nie jest istotna w procesie klasyfikacji motyli.

	NASYC_SR	ZL_SREDN	ZL_STDDE	NB_STDDE
Ranga	4	3	1	2
Błąd	0,3379373	0,3805457	0,4844063	0,4408633
Iloraz	1,034081	1,164462	1,482273	1,349033
Ranga	4	3	1	2
Błąd	0,3232238	0,3502293	0,4985006	0,4493311
Iloraz	1,132529	1,227153	1,746674	1,574391

Rys. 8. Analiza wrażliwości sieci neuronowej *MLP* (4:2-3:1)


Fig. 8. Sensitivity analysis of neural network type *MLP* (4:2-3:1)

4. Podsumowanie

W trakcie prac nad wygenerowaniem *SSN* okazało się, że zbyt duża liczbazmiennych zawarta w zbiorze uczącym może być przeszkodą w prawidłowym wygenerowaniu modelu neuronowego. Nadmierna ilość informacji negatywnie wpływa na generowany model, a co za tym idzie wytworzona sieć nie spełnia kryteriów jakości i nie działa poprawnie. Zasadnym jest ograniczanie liczby zmiennych uczących do proporcji 10 przypadków uczących na 1 zmienną wyjściową [4].

Wygenerowana sieć *MLP* o strukturze 4:2-3:1 posiada jakość walidacyjną na poziomie 0,878788. Oznacza to, iż proporcja prawidłowo zakwalifikowanych przypadków wynosi 0,878788, czyli na 100 przedstawionych obrazów cyfrowych sieć rozpoznaje prawidłowo 88 z nich. Sieć do prawidłowego działania, klasyfikacji czterech gatunków motyli z rodziny *Papilionidae*, potrzebuje czterech zmiennych reprezentatywnych (rys. 9):

- zielony StdDev,
- niebieski StdDev,
- zielony średnia,
- nasylenie średnia.



Rys. 9. Schemat wygenerowanej sztucznej sieci neuronowej typu *MLP* (4:2-3:1)

Fig. 9. Diagram generated artificial neural network type *MLP* (4:2-3:1)

Zdjęcia owadów źle zakwalifikowanych były na ogół złej jakości (zaszumiane) lub nie można było wyodrębnić w nich żądanych cech charakterystycznych.

5. Wnioski

1. Została wykazana przydatność sieci neuronowych typu *MLP* w procesie rozpoznawania motyli prezentowanych w postaci obrazów cyfrowych, gdzie za kryterium klasyfikacyjne przyjęto ich ubarwienie.
2. Na efektywność wytworzonych sieci neuronowych ma wpływ jakość oraz ilość danych graficznych, niezbędnych w procesie budowania zbiorów uczących, przeznaczonych do generowania identyfikacyjnych modeli neuronowych.
3. Na poprawność działania wygenerowanych sieci neuronowych ma również wpływ właściwy dobór zmiennych wejściowych oraz liczba przypadków uczących zawartych w zbiorze treningowym.

6. Literatura

- [1] Jankowski M.: Elementy grafiki komputerowej. Wydawnictwa Naukowo-Techniczne, 2006.
- [2] Markowska-Kaczmar U., Kwaśnicka H.: Sieci neuronowe w zastosowaniach”, Wrocław, Oficyna Wydawnicza Politechniki Wrocławskiej, 2005.
- [3] Tadeusiewicz R., Flasiński M.: Rozpoznawanie obrazów. Warszawa, Państwowe Wydawnictwo Naukowe, 1991.
- [4] Tadeusiewicz R.: Sieci neuronowe. Warszawa, Akademia Oficyna Wydawnicza, 1993.
- [5] Tadeusiewicz R., Kohorda P.: Komputerowa analiza i przetwarzanie obrazów. Kraków, Wydawnictwo Fundacji Postępu Telekomunikacji, 1997.
- [6] Tadeusiewicz R.: Rozpoznawanie obrazów. Warszawa, 1998.
- [7] Zaborowicz M., Boniecki P., Świerczyński K.: System informatyczny *PiAO* jako narzędzie do akwizycji przetwarzania obrazów cyfrowych w procesie wytwarzania zbiorów uczących przeznaczonych do budowy modeli neuronowych. Journal of Research and Applications in Agricultural Engineering, 2010, Vol. 55(1) – w druku.